

Lassen sich Wertüberzeugungen und Selbstkonzept zum Verständnis Künstlicher Intelligenz durch KI-Modellierungsworkshops fördern?

SEBASTIAN GEISLER, POTSDAM; MARIELENA MENZEL, POTSDAM; STEPHANIE HOFMANN, KARLSRUHE; BENEDIKT WEYGANDT, BERLIN; SEBASTIAN BAUER, KARLSRUHE & SARAH SCHÖNBRODT, SALZBURG

Zusammenfassung: Inwiefern Lernende bereit sind, sich mit Künstlicher Intelligenz (KI) und ihrer Funktionsweise auseinanderzusetzen, hängt auch stark von ihrer Motivation ab. Im Beitrag stellen wir das Konzept von KI-Modellierungsworkshops im Rahmen von CAMMP vor und untersuchen in einer längsschnittlichen quantitativen Studie mit $N=123$ Schüler*innen, inwiefern die Workshops zu einer Motivationssteigerung in Bezug auf das Verstehen von KI beitragen. Dazu wurde Motivation im Rahmen der Erwartungs-Wert-Theorie konzeptualisiert und operationalisiert. Die Ergebnisse zeigen, dass die Workshops zwar nicht zu einer Zunahme der Wertüberzeugungen der Lernenden führen, jedoch das Selbstkonzept zum Verständnis von KI im Laufe der Workshops steigt.

Abstract: Whether students are willing to engage with Artificial Intelligence (AI) and its foundations is (among others) a function of their motivation. In this contribution we introduce the concept of AI-modeling workshops in the CAMMP education program. In a longitudinal quantitative study with $N = 123$ secondary students we analyse in which way the workshops contribute to fostering students AI related motivation. Motivation was conceptualized and operationalized in the sense of expectancy-value-theory. The results show that the workshops failed to foster students' values, however students' self-concept of understanding AI increased during the workshops.

1. Einleitung

Spätestens seit der Veröffentlichung von ChatGPT werden KI-Systeme aufgrund ihrer breiteren Verfügbarkeit und leichteren Bedienbarkeit vermehrt im schulischen Kontext eingesetzt – sowohl durch Lehrkräfte als auch Schüler*innen. Ferner ist abzusehen, dass sich in immer mehr beruflichen Kontexten ein kompetenter Umgang mit KI-Tools als vorteilhaft, wenn nicht gar notwendig herausstellen wird (KMK, 2024; mmb Institut et al., 2021; Eickelmann et al., 2024). Sowohl für einen gewinnbringenden Einsatz in zukünftigen beruflichen Kontexten als auch mit Blick auf mögliche Missbrauchspotentiale von KI wird ein grundsätzliches Verständnis der (algorithmischen) Grundlagen von KI-Anwendungen immer wichtiger werden (Chiu et al., 2021; Druga et al.,

2019). Inwiefern Schüler*innen bereit sind, sich mit diesen Grundlagen auseinanderzusetzen, und wie viel Anstrengung sie investieren, hängt im Wesentlichen auch von ihrer Motivation ab, KI verstehen zu wollen. Auch die Europäische Union betont in ihrem aktualisierten Digital Competence Framework for Citizens (DigComp 2.2) die Bedeutung von motivationalen Aspekten mit Bezug zu KI (Vuorikari et al., 2022). Daher ist eine Förderung der Motivation, sich mit dem Verständnis von KI zu beschäftigen, wünschenswert. In diesem Artikel stellen wir daher die an mehreren Universitäten entwickelten und durchgeführten KI-Modellierungsworkshops des Schüler*innenprogramms CAMMP (Computational And Mathematical Modeling Program, www.cammp.online) vor. In diesen Workshops werden die mathematischen Grundlagen der Methoden, die KI-Systemen zugrunde liegen, problembezogen vermittelt. Auf Basis der Erwartungs-Wert-Theorie untersuchen wir, inwiefern durch die Teilnahme an den KI-Modellierungsworkshops die Motivation, KI verstehen zu wollen, von Schüler*innen der Jahrgangsstufen 10 bis 13 gefördert werden kann. Die CAMMP-Workshops werden in Abschnitt 3 detaillierter beschrieben.

2. Theoretischer Hintergrund

In diesem Abschnitt wird zunächst das Verständnis von KI definiert und in Konzeptionen von AI Literacy eingebettet. Anschließend wird auf Motivation und deren Konzeptualisierung in der Erwartungs-Wert-Theorie eingegangen, bevor zuletzt ein Überblick über die Literatur zur Motivation in Bezug auf KI gegeben wird. Dabei wird eine Forschungslücke im Bereich Verständnis von KI identifiziert.

2.1 KI-Verständnis

Es existiert bislang keine konsensuale Definition von Künstlicher Intelligenz. Long und Magerko (2020) haben in ihrem Literaturreview eine Reihe von Definitionsversuchen zusammengestellt, welche die Vielfalt und Heterogenität der Perspektiven verdeutlichen. Die CAMMP-Workshops behandeln KI-Systeme, welche auf Basis gegebener Trainingsdaten mithilfe ausgewählter Methoden des Maschinellen Lernens (ML) aus vorher unbekannten Daten Prognosen erstellen bzw. diese Daten kategorisieren

(Schönbrodt et al., 2021). Da in diesem Artikel motivationale Effekte dieser Workshops untersucht werden, fokussieren wir uns hier primär auf diejenigen Aspekte der Definitionen, die sich auf mathematische Grundlagen von KI-Systemen beziehen. Andere Facetten der bei Long und Magerko (2020) zu findenden Definitionen, wie etwa die allgemeine Wahrnehmung von KI, sind zwar durchaus relevant, werden aber im Rahmen der eintägigen Workshops nicht speziell adressiert.

Der Begriff des Verständnisses ist ein zentraler Bestandteil in der aktuellen Diskussion von AI Literacy-Konzepten. In dem einflussreichen Übersichtsartikel von Long und Magerko werden unter AI Literacy solche Kompetenzen gefasst, welche Lernende dazu befähigen „KI-Technologien kritisch zu bewerten, effektiv mit KI zu kommunizieren und zusammenzuarbeiten und KI als Tool online, zu Hause und am Arbeitsplatz zu nutzen“ [Übers. d. Verf.] (Long & Magerko, 2020). Dabei ist nicht nur der Umgang mit KI-Systemen gemeint, sondern es wird auch die Vermittlung von deren Funktionsweise, insbesondere des ML, als zentraler Bestandteil von AI Literacy genannt (Long & Magerko, 2020). Programmierkenntnisse werden dabei nicht als notwendige Komponente angesehen, stattdessen wird das konzeptuelle Verständnis in den Vordergrund gestellt (Laupichler et al., 2023), eine Sichtweise die auch in den hier untersuchten Workshops verfolgt wird. Ng et al. (2021) identifizieren in einer Reviewstudie vier zentrale Aspekte von AI Literacy: KI kennen und verstehen („know and understand AI“), KI nutzen und anwenden („use and apply AI“), KI bewerten und entwickeln („evaluate and create AI“) und KI-Ethik. Der Aspekt „kennen und verstehen“ umfasst unter anderem das Verständnis der den KI-Anwendungen zugrunde liegenden Techniken und Konzepte (Burgsteiner et al., 2016; Kandlhofer et al., 2016).

Kompatibel hierzu erscheint das zentrale Lernziel der KI-Workshops von CAMMP, durch die Aufklärung der Rolle, Funktionsweise und Bedeutung der Mathematik bei der Konstruktion von KI-Systemen zu einem vertieften KI-Verständnis und zur Förderung der damit verbundenen Kompetenzen beizutragen. Gleichzeitig sollen die Workshops zur Entmystifizierung von KI beitragen, indem sie aufzeigen, wie solche Systeme mithilfe von Mathematik entwickelt werden, welche Rolle der Mensch dabei spielt und wie sie funktionieren. In den Workshops steht somit der Aspekt „kennen und verstehen“ im Mittelpunkt. Der Aspekt „bewerten und entwickeln“ wird ebenfalls thematisiert, da die Modelle im Workshop

kritisch evaluiert und auch in Hinblick auf ethische Fragen diskutiert werden.

In diesem Beitrag werden mit „KI-Verständnis“ also vor allem jene Facetten der AI Literacy adressiert, welche sich auf das Verständnis der Funktionsweise bestimmter KI-Technologien mit Methoden des ML beziehen und dabei die Rolle des Menschen und der Trainingsdaten reflektieren.

2.2 Konzeptualisierung von Motivation in der Erwartungs-Wert-Theorie

Wir konzeptualisieren Motivation im Rahmen der Erwartungs-Wert-Theorie. Diese beruht auf einem komplexen Modell nach Wigfield und Eccles (2000), welches Personenmerkmale sowie Erwartungen und Wertüberzeugungen vereint. Dieses Modell beschreibt die Motivation einer Person, eine Handlung auszuführen, sowie die Höhe der Anstrengungsbereitschaft für diese Handlung. Grundannahme ist dabei, dass Erfolgserwartungen (kann ich das tun?) und Wertüberzeugungen (will ich das tun?) gemeinsam die Motivation beeinflussen. Diese ist umso höher, je stärker Erfolgserwartungen und Wertüberzeugungen ausgeprägt sind.

Das Modell erfasst auf Seiten der Personenmerkmale zudem Prägungen des kulturellen Milieus, wie soziale Rollenbilder und genderspezifische Stereotype, sowie Selbstschemata, frühere Erfahrungen, Einstellungen und Ziele. Im schulischen Rahmen fällt darunter konkret die Präferenz von Fächern, welche beispielsweise im Kontext der Leistungsfachwahl widergespiegelt wird (Eccles & Wigfield, 2020).

Erfolgserwartungen beschreiben die Überzeugung einer Person, eine anstehende Aufgabe oder Handlung erfolgreich zu bewältigen. Wenn sich die Motivation weniger auf konkrete Aufgaben, sondern auf eher grobe Bereiche wie domänenspezifisches Verständnis bzw. domänenspezifische Aktivitäten richtet, dann können diese Erwartungen mit dem domänenspezifischen Selbstkonzept beschrieben werden (Eccles & Wigfield, 2020). Das Selbstkonzept wird als Einschätzung über die eigene Fähigkeit, in dem fraglichen Bereich Leistung erbringen zu können, konzeptualisiert (Eccles & Wigfield, 2023). In dem vorliegenden Beitrag betrifft das domänenspezifische Selbstkonzept den Bereich „Verständnis von KI“. Verschiedene Einflussfaktoren und Mechanismen zur Anpassung des Selbstkonzepts werden diskutiert. Bong und Skaalvik (2003) nennen insbesondere Erfolgs- und Misserfolgserlebnisse als zentralen Einflussfaktor. Zudem wirkt sich Feedback, von als kompetent wahrgenommenen Personen positiv aus,

wenn dieses konstruktiv und zielgerichtet bzw. individuell ist. Außerdem spielen Vergleichsprozesse – sogenannte Frames of Reference – eine wichtige Rolle (Marsh, 1990). Dazu gehören beispielsweise temporale Vergleiche, bei denen Schüler*innen ihren aktuellen Leistungsstand mit vorangegangenen Leistungen vergleichen. In kriterialen Vergleichen orientieren Schüler*innen sich an objektiven Standards – auch hier spielt individuelles Feedback eine wichtige Rolle.

Die Wertüberzeugungen beschreiben unterschiedliche Komponenten der subjektiven Bewertung des angesprochenen Gegenstands (bspw. konkrete Aktivitäten oder das Verstehen von KI-Grundlagen). Dabei setzen sich die Wertüberzeugungen aus vier Konstrukten zusammen: Der Intrinsic Value umfasst die antizipierte Freude und das persönliche Interesse am angesprochenen Gegenstand. Dieses Konstrukt ist der intrinsischen Motivation recht nah. Im vorliegenden Beitrag wird dieses Konstrukt bezogen auf das Verstehen von KI beispielsweise erfasst durch das Item „KI zu verstehen, finde ich spannend“. Ähnlich wie Interesse, lässt sich der Intrinsic Value zum Beispiel über geeignete Kontexte fördern. Im Zusammenhang mit Modellierungen haben Schulze Elfringhoff und Schukajlow (2021) berichtet, dass insbesondere Kontexte, die für Schüler*innen mit positiven Emotionen verbunden sind, sich vorteilhaft auswirken. Zudem haben originelle Kontexte sowie ein Neuigkeitswert einen positiven Einfluss (Vorst et al., 2018). Des Weiteren wirken sich positive Erfolgserwartungen auch positiv auf den Intrinsic Value aus (Schulze Elfringhoff & Schukajlow, 2021), sodass ein enger Zusammenhang zwischen Selbstkonzept und Intrinsic Value besteht und Faktoren wie zielgerichtetes Feedback indirekt auch den Intrinsic Value steigern können.

Der Attainment Value beschreibt die von einer Person wahrgenommene Wichtigkeit, gut in einem Bereich sein zu wollen und hängt mit ihrer Identität zusammen (Wigfield et al., 2020). Dabei haben soziale und gesellschaftliche Rollenbilder einen Einfluss, indem sie Erwartungen darüber erzeugen, welche Fähigkeiten und Interessen mit bestimmten Rollen oder Identitäten verknüpft werden. Der Attainment Value gilt daher auch eher als stabil und insbesondere in kurzen Interventionen als schwer beeinflussbar. Dementsprechend existiert wenig Forschung zu Mechanismen, um den Attainment Value zu fördern. Eccles und Wigfield (2020) schlagen jedoch vor, explizite Verknüpfungen mit den persönlichen Zielen und der Identität der Schüler*innen herzustellen, um den Attainment Value zu fördern. Der

Attainment Value wird u. a. mit „Es ist mir wichtig, KI gut zu verstehen“ erfasst.

Mit dem Utility Value kann beschrieben werden, wie nützlich der angesprochene Lerngegenstand erscheint. Dabei werden verschiedene Perspektiven hinsichtlich des (zukünftigen) alltäglichen Lebens, der Karriere oder der Schullaufbahn einbezogen (Gaspard et al., 2015). Mit „KI zu verstehen, wird für mein späteres Leben wichtig sein“ wird beispielsweise die Perspektive auf das zukünftige Leben allgemein erfragt. Zur Steigerung des Utility Values haben sich Interventionen, in denen die Relevanz eines Inhalts explizit mit Lernenden reflektiert werden, wiederholt in Studien als effektiv erwiesen (siehe z. B. Hulleman und Harackiewicz, 2009). Derartige Reflexionen können zudem einen positiven Effekt auf den Intrinsic Value nehmen.

Intrinsic Value, Attainment Value und Utility Value stellen die positiven Komponenten der Wertüberzeugungen dar. Die negative Komponente der Wertüberzeugungen werden durch die Costs beschrieben. Diese umfassen die antizipierte Anstrengung, die zur Bewältigung einer Handlung aufgebracht werden muss, sowie die damit verbundenen emotionalen Costs wie Frustration oder Scham. Außerdem werden hier Opportunitätskosten berücksichtigt, welche durch entgangene Alternativen entstehen, wenn die Ausführung einer Handlung den Raum einnimmt, der sonst mit anderen Tätigkeiten gefüllt werden könnte (Gaspard et al., 2015). Anstrengungs- und emotionale Kosten können zum Beispiel durch klar strukturierte Lernsituationen, die zwar fordernd sind, aber nicht kognitiv überfordern, gering gehalten werden. Zudem kann so auch das Selbstkonzept gefördert werden.

Die Wertüberzeugungen sind als Gesamtwert zu begreifen, welcher sich aus den einzelnen Komponenten ergibt. Die Gewichtung dieser Komponenten ist individuell für jede Person unterschiedlich, sodass sich die Wertüberzeugungen von Person zu Person stark unterscheiden können (Eccles & Wigfield, 2020). Wenn der Wert insgesamt hoch ist, ist die Person motiviert, eine Handlung auszuführen. Die Anstrengungsbereitschaft hängt dabei von den Wertüberzeugungen und dem Selbstkonzept für die betrachtete Domäne ab. Dies zeigt sich in verschiedenen Studien insbesondere auch für Mathematik (zusammengefasst in Wigfield et al., 2020). Abbildung 1 fasst die Annahmen und theoretischen Konstrukte der Erwartungs-Wert-Theorie (vereinfacht) zusammen.




Abb. 1: Vereinfachtes Modell zur Erwartungs-Wert-Theorie (adaptiert von Eccles und Wigfield, 2020)

2.3 Literatur zur Motivation in Bezug auf KI

Bisherige Studien zeigen, dass eine höhere Motivation in Bezug auf KI auch mit einer größeren Akzeptanz für KI-Tools einhergeht (für ein Review siehe Kelly et al., 2023). Viele dieser Studien fokussieren allerdings auf Studierende oder Lehrkräfte, während vergleichsweise wenig Studien die Motivation von Schüler*innen untersuchen. Zudem wird in fast allen Studien die Motivation zur Nutzung von KI erfragt, während Motivation, KI zu verstehen, bislang kaum erforscht ist.

Yurt und Karsaci (2023) haben auf Grundlage der Erwartungs-Wert-Theorie einen Fragebogen zur Motivation in Bezug auf KI erstellt und konnten zeigen, dass eine derartige Konzeptualisierung zur validen Messung der Wertfacetten geeignet ist. Allerdings berichten sie keine Ergebnisse zur Ausprägung der Wertfacetten bei Lernenden.

Bei Studierenden berichten einige Studien positive Effekte von Wertfacetten auf den Umgang mit KI. So korrelieren Intrinsic, Attainment und Utility Value bei Studierenden positiv mit der Nutzungsintention bezüglich KI, während Costs mit einer geringeren Nutzungsintention bei Studierenden einhergehen (Chan & Zhou, 2023). Auch Wang et al. (2023) berichten, dass sich ein höherer Utility Value und ein stärkeres Selbstkonzept positiv auf die Lernbereitschaft bezüglich KI auswirken. Lai et al. (2023) haben den Zusammenhang zwischen Wertüberzeugungen und der Nutzungsintention bezüglich ChatGPT untersucht und konnten bei Studierenden feststellen, dass Intrinsic Value und Utility Value mit einer höheren Nutzungsintention einhergingen. Studierende sind also eher geneigt ChatGPT zu nutzen, wenn sie ChatGPT als nützlich wahrnehmen und Freude im Umgang mit dieser generativen KI empfinden. Zu ähnlichen Ergebnissen kommen Acosta-Enriquez et al. (2024), die zusätzlich untersucht haben, ob das Geschlecht einen Einfluss auf den Zusammenhang zwischen Affekt und Nutzungsintention von ChatGPT hat. Allerdings konnten in dieser Studie keine

moderierenden Effekte des Geschlechts festgestellt werden. Chan et al. (2023) kommen zu dem Schluss, dass Studierende generativer KI positiv gegenüberstehen. Wang et al. (2022) berichten, dass Angst vor KI (als emotionale Costs) mit einer geringeren intrinsischen Motivation in Bezug auf KI einhergeht, während die intrinsische Motivation einen positiven Einfluss auf KI-Nutzungsintention besitzt. Lehrkräfte scheinen der Verwendung von KI im Unterricht positiv gegenüberzustehen (Pöhr et al., 2024). Lehrkräfte, die KI (im Sinne der Erwartungs-Wert-Theorie) wertschätzen, nutzen diese auch eher in unterrichtlichen Kontexten. Männer berichteten in dieser Studie höhere Wertüberzeugungen als Frauen (Collie & Martin, 2024).

Studien zu Genderunterschieden bei KI-bezogener Motivation kommen jedoch zu uneinheitlichen Ergebnissen. Für Studierende konnten Katsantonis et al. (2024) keine Genderunterschiede beim Utility Value feststellen: Studenten und Studentinnen unterschieden sich nicht mit Blick auf die Relevanz, die sie KI beimaßen. Im Gegensatz dazu berichten Stöhr et al. (2024), dass Studentinnen weniger positive Einstellungen zu KI aufweisen als Studenten. Studentinnen scheinen jedoch einen stärkeren Wert auf ethische Überlegungen zu KI zu legen (Jang et al., 2022). Bei Schüler*innen scheint es indes Genderunterschiede zugunsten der Jungen zu geben, diese zeigen positivere Einstellungen sowie eine höhere Motivation, sich mit KI auseinanderzusetzen (Kim & Lee, 2023; Lin et al., 2021).

Bislang haben nur wenige Studien untersucht, wie die KI-bezogene Motivation gefördert werden kann. Eine unterstützende Lernumgebung kann sich bei Studierenden positiv auswirken. Wang et al. (2023) nennen als relevante Charakteristika solcher Lernumgebungen insbesondere die Verfügbarkeit und den einfachen Zugang zu Unterstützung durch Lehrkräfte sowie ein insgesamt positives Klima innerhalb der Lehrveranstaltung zum Lernen in Bezug auf KI. Beides wirkt sich positiv auf den Utility Value und das KI-bezogene Selbstkonzept aus. Auch Chiu et al. (2023) konnten zeigen, dass Unterstützung durch die Lehrkraft einen positiven Effekt auf KI-bezogene Motivation hat. Projektbasiertes Lernen mit KI-Bezug scheint sich bei Schüler*innen positiv auf die Motivation, sich mit KI zu beschäftigen, auszuwirken (Ng et al., 2024). Allerdings fehlt in der Studie von Ng et al. (2024) eine Kontrollgruppe. Im Vergleich zum Lernen mit eBooks hat das Lernen mit einer gamification-Plattform einen positiven Effekt auf den Intrinsic und den Utility Value von Schüler*innen,

nicht jedoch auf ihr Selbstkonzept in Bezug auf KI (Ng et al., 2023).

Insgesamt zeigt sich, dass Forschung dazu fehlt, welche Motivation Schüler*innen in Bezug auf das Verständnis von KI haben und inwiefern diese Motivation in Interventionen gesteigert werden kann.

3. KI-Workshops im Rahmen von CAMMP

Allgemeines Ziel der CAMMP Workshops, sogenannte CAMMP days, ist es, die Bedeutung von Mathematik und insbesondere von computergestützter mathematischer Modellierung für Alltag, Industrie und Forschung erfahrbar zu machen. Dazu werden in den Workshops reale Probleme und Fragestellungen ausgewählt, die sich auf einen außermathematischen Kontext beziehen.

Die Workshops setzen sich mit dem Lösen von Problemen aus verschiedenen Anwendungsbereichen auseinander, einer davon ist der Bereich KI.

Die Lernziele der KI-Workshops orientieren sich dabei am Kompetenzrahmen von Long und Magerko (2020), der sich wie die CAMMP days an Lernende ohne technischen Hintergrund richtet. Sie umfassen Kompetenzen zur Repräsentation von und dem Umgang mit Daten, dem „Lernen aus Daten“, zu den einzelnen Schritten des ML und zur Rolle des Menschen bei der Entwicklung von KI-Systemen (Long & Magerko, 2020) und spezifizieren diese mit einer mathematischen Perspektive. Diese Lernziele werden verfolgt, indem Lernende unter Anleitung ein ausgewähltes KI-System basierend auf Methoden des ML entwickeln.

3.1 Designprinzipien der Workshops und Förderung von Motivation

Im Folgenden werden die Designprinzipien vorgestellt, an denen sich alle in der vorliegenden Studie untersuchten KI-Workshops orientieren. Zudem wird dargestellt, wie diese Prinzipien zur Förderung von KI-Verständnis und der Förderung von Selbstkonzept und Wertüberzeugungen zum Verständnis von KI beitragen sollen.

Wahl der Problemstellung

Im Sinne des CAMMP-Programms werden in den Workshops reale Probleme modelliert. Ziel ist es, ein Verständnis von KI aufzubauen, indem reale KI-Anwendungen wie Bildklassifizierung oder Spracherkennung angeleitet entwickelt werden, anstatt ML-Methoden losgelöst von der Realität anhand fiktiver Daten und Fragestellungen einzuführen. Durch die Entwicklung eines eigenen KI-Systems soll ein

grundlegendes Verständnis der Funktionsweise der betrachteten KI-Anwendung ermöglicht werden – im Sinne der Annahme, dass man etwas versteht, wenn man nachvollziehen kann, wie es geschaffen wurde. Die konkreten Kontexte werden insbesondere mit Blick auf Intrinsic und Utility Value ausgewählt. Dabei sollen alle Kontexte relevant im Sinne von Burkhardt (1989) sein. Es werden also Kontexte ausgewählt, die für Lernende potenziell ansprechend oder bedeutungsvoll erscheinen. Desweiteren sollen die Kontexte für Schüler*innen möglichst mit positiven Emotionen belegt sein (Schulze Elfinghoff & Schukajlow, 2021) und einen gewissen Originalität bzw. einen Neuigkeitswert besitzen (Vorst et al., 2018).

Dem Thema KI kann durch dessen Medienpräsenz und Neuigkeitswert eine Relevanz für die Lernenden zugewiesen werden. Für die Workshops werden zudem KI-Anwendungen aus dem Lebensalltag der Lernenden gewählt, um so die Relevanz der Problemstellung zu verstärken sowie positive Emotionen zu begünstigen und den Intrinsic Value zu stärken.

Zudem sollen die betrachteten Probleme authentisch sein. Dabei wird die Authentizität auf Niss zurückgeführt, welcher Problemstellungen dann als authentisch bezeichnet, wenn sie in reale Praktiken oder Fachgebiete außerhalb der Mathematik eingebettet sind und sich mit üblichen Problemen und Fragestellungen dieses Fachgebietes befassen (Niss, 1992, zitiert nach Kaiser & Schwarz, 2010; Vos, 2011). Neben der Authentizität hinsichtlich der Fragestellung und deren Sachkontext wird auch die Authentizität im Bezug auf die Verwendung der Mathematik berücksichtigt. Die Verwendung der für die Lösung des Problems genutzten Mathematik wird als authentisch bezeichnet, wenn sie realistisch im Hinblick darauf ist, dass sie in der Realität (gegebenenfalls in komplexerer Form) tatsächlich zum Lösen des Problems verwendet wird (Vos, 2011). Die Authentizität des Kontextes, aber insbesondere die Authentizität der Fragestellung wird von Vos (2018) als wichtig für die Motivation und Leistung der Lernenden angesehen.

Aufbau und inhaltliche Gestaltung

Die Workshops dauern zwischen vier und fünf Stunden und finden im Rahmen von Tagesworkshops statt (Wohak et al. 2021). Jeder Workshop beginnt mit einer Einführung in die jeweilige reale Problemstellung sowie einer kurzen Erläuterung des Prozesses der mathematischen Modellierung anhand eines vierschrittigen Modellierungskreislaufes, angelehnt an Blum (1985). Im Laufe des Workshops werden die

absolvierten Modellierungsschritte wiederholt in den Kreislauf eingeordnet. Dieser dient somit als strukturierendes und zugleich metakognitives Werkzeug (Schukajlow et al., 2011). So kann er dazu beitragen, eine Überforderung der Lernenden (wie sie teilweise bei zu offen erlebten Lernsituationen auftritt) und damit hohe Costs zu verhindern.

Bevor die Komplexität der Modellierung schrittweise gesteigert wird, wird zunächst ein möglichst einfach zugängliches Modell entwickelt, um die erlebten Costs möglichst gering zu halten. Dadurch sollen frühzeitig Erfolgserlebnisse ermöglicht und das Selbstkonzept der Schüler*innen gestärkt werden. Dafür wird etwa eine Reduktion der Dimension des Problems durchgeführt, wodurch die konzeptionellen Hürden der Höherdimensionalität von Problemen im KI-Kontext – die häufig mit formalen Herausforderungen durch komplexere Notation einhergehen – umgangen werden.

Dieses vereinfachte erste Modell dient als Ausgangspunkt und wird durch die schrittweise Anpassung der Annahmen an die Problemsituation sowie die Nutzung komplexerer mathematischer Methoden verbessert. Der Modellierungskreislauf wird somit mehrfach durchlaufen.

Eine weitere Hürde entsteht dabei durch die formale Darstellung von Optimierungsproblemen, wie sie typischerweise bei ML-Methoden auftreten. Dieser wird begegnet, indem in den Workshops bewusst auf eine symbolische Notation verzichtet und stattdessen eine verbale Beschreibung des Optimierungsproblems verwendet wird.

Die Workshops knüpfen wesentlich an das Vorwissen der Lernenden an, da die mathematischen Modelle zu einem großen Teil auf schulmathematischen Inhalten basieren. Dieses Anknüpfen an bereits vorhandenes Wissen soll ebenfalls das Selbstkonzept der Lernenden stärken, indem sie erleben, dass sie sich ML-Methoden auf Basis ihrer bisherigen Kenntnisse erfolgreich erschließen können. Die für die Schüler*innen neuen mathematischen Konzepte, Methoden und Verfahren werden problembezogen eingeführt. Auf diese Weise wird das Lernen stärker im Kontext realer Anwendungen verankert und die Relevanz der mathematischen Inhalte und Methoden für die Praxis unmittelbar sichtbar. Ziel ist es, die Bedeutung eines Verständnisses von KI für die reale Welt deutlich zu machen, zu reflektieren und dadurch den Utility Value zu steigern.

Zudem werden ethische Implikationen (Long & Margerko, 2020) in den Workshops adressiert, sodass

sich Lernende eine reflektierte Meinung über Nutzen und Gefahren bei der Anwendung und der (Mit-)Entwicklung von KI-Systemen bilden können. Durch das vorher aufgebaute Verständnis über die Funktionsweise von KI-Systemen können die Fähigkeiten des KI-Systems sowie einige ethische Aspekte insbesondere bei der Entwicklung von KI-Systemen überhaupt erst identifiziert werden (z.B. Diskriminierung als Folge von statistischen Verzerrungen). Die Auseinandersetzung mit der Funktionsweise von KI-Systemen bildet daher die Basis, um Chancen und Risiken von KI sinnvoll bewerten zu können. Diese Verknüpfung von mathematischer Auseinandersetzung und ethischer Reflektion soll einen positiven Effekt auf den Utility Value (also den Nutzen, KI zu verstehen) haben. Gleichzeitig soll die Motivation von Schüler*innen durch die Beschäftigung mit ethischen Fragen gefördert werden (Jang et al., 2022).

Methodische Umsetzung

In den Workshops wechseln sich Plenums- und Gruppenarbeitsphasen ab. In den Gruppenarbeitsphasen erarbeiten die Lernenden mithilfe von vorbereiteten digitalen Lernumgebungen ein mathematisches Modell für die betrachtete Problemstellung – im Fall der KI-Workshops entsprechende ML-Methoden.

Die Lernmaterialien bestehen aus Jupyter Notebooks (jupyter.org), welche didaktisch aufbereitet wurden. Der Zugang zu den Lernmaterialien wird unter www.cammp.online/214.php beschrieben. Die Notebooks ermöglichen einerseits, große Datenmengen zu verarbeiten und komplexe numerische Berechnungen zu absolvieren und erlauben andererseits die Realisierung von didaktischen Elementen, wie die Integration von gestuften Hilfen oder automatischem Feedback zur Eingabe der Lernenden. Das Feedback soll insbesondere zu einer Förderung des Selbstkonzepts beitragen. Gestufte Lernhilfen können zudem die erlebten Costs verringern. Ergänzend steht den Lernenden die Unterstützung durch Betreuende zur Verfügung, falls die im Material bereitgestellten Hilfestellungen nicht ausreichen.

Die Jupyter Notebooks können im Browser bearbeitet werden und sind so gestaltet, dass für die Bearbeitung der Aufgaben keine Programmierkenntnisse notwendig sind. Stattdessen wird ein Lückentextansatz umgesetzt (Schönbrodt et al., 2022).

3.2 Themen der Workshops

Die vorliegende Studie wurde im Zuge von CAMMP days zu drei KI-bezogenen Themen durchgeführt. In

allen drei Workshops wird eine Methode aus dem Bereich des sogenannten überwachten maschinellen Lernens problembezogen erarbeitet und sie folgen den zuvor beschriebenen Designprinzipien. Die Workshops richten sich an Schüler*innen der Oberstufe und bauen auf Inhalten ab Ende Sekundarstufe 1 auf. Die Themen der in die Studie einbezogenen drei Workshops lauten:

- **Bildklassifizierung im Kontext des autonomen Fahrens:** Die Lernenden entwickeln ein mathematisches Modell zur Klassifizierung von Bildern von Ampeln. Als ML-Methode wird die Support Vector Machine zur Lösung eines Klassifikationsproblems von den Lernenden konstruiert (Schönbrodt et al., 2021).
- **Spracherkennung:** Die Lernenden entwickeln ein mathematisches Modell zur Erkennung von gesprochener Sprache. Die zugrundeliegende ML-Methode ist die k-nearest-neighbor-Methode zur Klassifikation (Hofmann, 2025).
- **Empfehlungssysteme:** Die Lernenden entwickeln ein Empfehlungssystem für Filme und wenden dieses auf einen von Netflix veröffentlichten Datensatz an. Die zugrundeliegende Methode zur Lösung dieses Regressionsproblems beruht auf einer Matrix-Faktorisierung (Schönbrodt & Frank, 2022).

3.3 Beispiel: Workshop zur Bildklassifizierung

Exemplarisch wird hier der Workshop zur Bildklassifizierung beschrieben.

Im Workshop zur Bildklassifizierung rekonstruieren Oberstufenschüler*innen schrittweise und angeleitet eine ML-Methode (Support Vector Machine) zur Klassifikation von Ampelbildern (Schönbrodt et al., 2021). Abschließend können als weitere Anwendungen die Handschrifterkennung und die Gesichtserkennung untersucht werden. In diesem Abschnitt werden die zentralen Erarbeitungsschritte, die die Lernenden durchlaufen, beschrieben. Die methodischen Elemente und der Ablauf des Workshops entsprechen den obigen allgemeinen Ausführungen zu den CAMMP days.

Die Bildklassifizierung wird als Thema gewählt, da sie aufgrund zahlreicher Anwendungsbezüge in der Lebensrealität der Lernenden ein relevantes und damit motivationsförderndes Thema darstellt. An die Alltagsrelevanz knüpft der einleitende Inputvortrag durch eine Lehrkraft mit eingebetteten Diskussionsfragen an: Anwendungen der Bildklassifizierung werden gesammelt und die Problemstellung eingeführt

– die Entwicklung eines Klassifizierungsmodells für Bilder. Das authentische Beispiel der Ampelerkennung beim autonomen Fahren soll die Lernenden in die Lage von Entwickler*innen beim autonomen Fahren versetzen. Da Bilder, bestehend aus zahlreichen Pixeln, relativ komplexe Daten darstellen, wird das Problem stark vereinfacht, indem lediglich ein Pixel aus dem oberen und ein Pixel aus dem unteren Ampellicht betrachtet wird. Diese Vereinfachung soll die erlebten Costs gering halten. Durch Transformation bunter Ampelbilder in Schwarzweiß-Bilder ermitteln die Lernenden in der ersten Erarbeitungsphase mit Jupyter Notebooks für jedes Ampelbild einen 2-dimensionalen Datenpunkt (Abb. 2).




Abb. 2: Vereinfachte Darstellung von Ampelbildern (oben), sowie der Trainingsdatensatz mit verschiedenen Trenngeraden (unten) (Schönbrodt et al., 2021)

Erster Modellansatz: Ein Trainingsdatensatz, bestehend aus zahlreichen 2-Pixel-Bildern von grünen und roten Ampeln (Abb. 2), wird grafisch für die Lernenden aufbereitet. Die Datenpunkte der beiden Klassen sind linear durch eine Trenngerade separierbar. Diese ordnet beliebige Datenpunkte je nach Lage der entsprechenden Klasse zu. Die Lernenden arbeiten zunächst mit Graphen linearer Funktionen und entwickeln ein Kriterium für die Wahl der optimalen Trenngerade (maximaler datenpunktfreier Bereich rund um die Gerade). Um ein erstes Erfolgserlebnis zu garantieren und das Selbstkonzept zu stärken, bestimmen sie die optimale Trenngerade mithilfe von interaktiven Grafiken zunächst händisch.

Modellerweiterung I: Eine Limitation der Verwendung von Graphen linearer Funktionen ist, dass senkrechte Trenngeraden nicht dargestellt werden können. Daher wird die Normalvektorform von Geraden eingeführt, mit denen auch senkrechte

Trenngeraden dargestellt werden können. Die Lernenden mathematisieren das bereits zuvor diskutierte Optimalitätskriterium (maximaler datenpunktfreier Bereich), indem sie eine Formel für den Abstand eines beliebigen Punktes zur Trenngeraden aufstellen. Dieser Abstand soll für alle Datenpunkte maximal werden. Um die Costs gering zu halten, verbalisieren die Lernenden das Optimierungsproblem lediglich. Eine formale, symbolische Beschreibung des Problems sowie das Lösen dessen wird für ein grundlegendes Verständnis der ML-Methode nicht für notwendig erachtet und daher nicht von den Lernenden verlangt. Gleichzeitig wird den Lernenden dabei vermittelt, dass die iterative Bestimmung der optimalen Trenngeraden als repetitive Aufgabe effizient an den Computer ausgelagert werden kann und eine Stärke maschineller Lernverfahren wesentlich in der schnellen Ausführung solcher Berechnungen durch digitale Werkzeuge liegt.

Modellerweiterung II: Um die Komplexität langsam zu steigern, werden erst in einer zweiten Modellerweiterung ein drittes (mittleres) Ampellicht hinzegenommen und damit dreidimensionale Inputdaten betrachtet. Die Daten können durch Trennebenen separiert werden. Die Zuordnung neuer Datenpunkte erfolgt über eine Fallunterscheidung welche im Wesentlichen auf dem Skalarprodukt beruht (Schönbrodt et al., 2021).

Der Workshop baut damit auf zentralen Inhalten des analytischen Geometrieunterrichts auf: Ebenen und Geraden sollen in Parameter oder Normalenform dargestellt werden, Abstände zwischen Punkt und Gerade beziehungsweise Punkt und Ebene bestimmt werden und das Skalarprodukt sowie dessen geometrische Interpretation genutzt werden, um neue Datenpunkte zu klassifizieren. Indem diese aus dem Schulunterricht bekannten Konzepte und damit das Vorwissen der Schüler*innen aufgegriffen werden, um die ML-Methode zu entwickeln, soll das Selbstkonzept der Lernenden gestärkt werden.

Anschließend wird das Modell zur Klassifizierung von Bildern bestehend aus deutlich mehr Pixeln eingesetzt. Konkret wird ein Datensatz aus Bildern handgeschriebener Ziffern (0 bis 9) verwendet. Im Plenum wird reflektiert, dass das Modell aufgrund der erhöhten Datenmenge nun basierend auf der ermittelten Entscheidungsregel computergestützt trainiert werden muss. Das trainierte Modell wird dann basierend auf Testdaten validiert. Dazu werden die Konfusionsmatrix und die Genauigkeit eingeführt. Die Werte der Konfusionsmatrix und die Genauigkeit werden hinsichtlich der Eignung des Modells für die

Ziffernerkennung interpretiert. Die Lernenden diskutieren zudem, welche Ziffern häufig falsch klassifiziert werden und woran dies mit Blick auf die verwendeten Trainingsdaten liegen kann. Auf diese Weise werden die Grenzen des Modells sichtbar. Den Lernenden soll dabei deutlich werden: Wer die Funktionsweise eines KI-Systems versteht, kann auch dessen Grenzen und damit seine Eignung für spezifische Einsatzszenarien besser einschätzen. Die Verknüpfung von Funktionsweise und Grenzen zielt somit auf eine Steigerung des Utility Value ab. Das Erleben von Grenzen kann ebenfalls zur Entmystifizierung beitragen und durch den Neuigkeitswerts dieser Erkenntnis den Intrinsic Value ansprechen.

Abschließend sammeln die Lernenden weitere Anwendungsmöglichkeiten der Bildklassifizierung. So wird deutlich gemacht, dass die Bildklassifizierung auch in anderen Anwendungsbereichen eine Rolle spielt, das Verstehen von KI und ML-Algorithmen somit für viele Bereiche insbesondere auch im Alltag der Lernenden nützlich ist. Eine positive Auswirkung auf den Utility Value ist daher zu erwarten. Die Bildklassifizierung wird schließlich kritisch bewertet und ihre Anwendungen hinsichtlich eines sinnvollen und eines gesellschaftlich oder ethisch problematischen Einsatzes eingeordnet.

4. Forschungsfragen

Ziel der vorliegenden Studie ist, zu untersuchen, inwiefern die drei KI-CAMMP days einen positiven Einfluss auf die Motivation in Bezug auf das Verstehen von KI haben und ob alle Schüler*innen gleichermaßen profitieren. Im Sinne des vereinfachten Modells zur Erwartungs-Wert-Theorie (Abb. 1) berücksichtigen wir als relevante Personenmerkmale das Geschlecht sowie die Leistungskurswahl. Da ein tieferes Verständnis der Funktionsweisen von KI-Algorithmen in Zukunft immer wichtiger wird (Eickelmann et al., 2024), wurde explizit die Motivation in Bezug auf das Verständnis von KI untersucht. Damit ergeben sich die folgenden drei Forschungsfragen:

- 1) Inwiefern unterscheiden sich Wertüberzeugungen und Selbstkonzept zum Verständnis von KI vor und nach den CAMMP days?

Da die Relevanz des Verständnisses von KI in den Workshops für die Einschätzung von Grenzen und Potentialen von KI-Systemen exemplifiziert wird und zudem relevante Kontexte (z. B. Netflix) aus der Lebenswelt der Schüler*innen genutzt werden, erwarten wir eine Steigerung von Intrinsic und Utility Value. Der Attainment Value gilt als eher stabil, so dass wir bei der kurzen Intervention keine signifikanten

Effekte erwarten. Die unterstützende und strukturierte Lernumgebung (u. a. mit gestuften Lernhilfen und automatischem Lösungsfeedback) soll einerseits mögliche Costs senken (obwohl sich viele Schüler*innen vermutlich noch nicht tiefergehend mit den mathematischen Grundlagen von KI-Systemen beschäftigt haben) und gleichzeitig durch die Möglichkeit der selbstständigen Bearbeitung Erfolgserlebnisse ermöglichen sowie kriteriale Vergleiche anhand des Feedbacks und somit das Selbstkonzept stärken. Zudem ist davon auszugehen, dass es durch den Lernzuwachs zu den Hintergründen von KI auch zu vorteilhaften temporalen Vergleichen der Schüler*innen kommt.

- 2) Unterscheiden sich Selbstkonzept und Wertüberzeugungen in Bezug auf das Verständnis von KI von Schülerinnen und Schülern vor und nach den CAMMP days?

Auch wenn bisherige Studien widersprüchliche Ergebnisse zu Genderunterschieden berichtet haben, scheinen Schülerinnen geringere Wertüberzeugungen als Schüler aufzuweisen. Daher erwarten wir entsprechende Unterschiede vor den Workshops. Bezüglich der Entwicklung ist die zweite Forschungsfrage eher explorativer Natur, da bisher kaum empirische Erkenntnisse zu Designprinzipien von KI-Workshops in Bezug auf Geschlechterunterschiede vorliegen. Da KI-Ethik expliziter Bestandteil der Workshops ist, erwarten wir allerdings eine Steigerung des Intrinsic Values bei Schülerinnen.

- 3) Unterscheiden sich Selbstkonzept und Wertüberzeugungen in Bezug auf das Verständnis von KI von Schüler*innen mit und ohne Leistungskurs Mathematik vor und nach den CAMMP days?

Wir erwarten, dass Schüler*innen mit Mathematikleistungskurs höhere Wertüberzeugungen und ein positiveres Selbstkonzept bezüglich des Verstehens von KI aufweisen als Schüler*innen ohne Mathematikleistungskurs, da sie mehr mathematisches Vorwissen mitbringen. Wir haben jedoch keine spezifische Hypothese, inwiefern sich Selbstkonzept und Wertfacetten in beiden Gruppen im Rahmen der CAMMP days entwickeln.

5. Methodik

5.1 Stichprobe und Design

123 Schüler*innen aus Baden-Württemberg der Jahrgangsstufen 11 bis 13 haben im Rahmen der CAMMP days an der Studie teilgenommen (Durchschnittsalter: 16 Jahre; 48 männlich, 64 weiblich,

11 ohne Angabe des Geschlechts). Die Teilnahme an den Workshops erfolgt im Kursverbund – es handelte sich bei den Lerngruppen folglich um reguläre Oberstufenkurse. Dabei haben 77 Lernende einen Leistungskurs besucht (40 männlich, 37 weiblich) und 37 Schüler*innen einen Grundkurs in Mathematik (8 männlich, 27 weiblich). Alle Schüler*innen haben nur jeweils einen der drei beschriebenen CAMMP Workshops besucht und wurden mittels Fragebögen zu Beginn und am Ende des Workshops zu ihren Wertüberzeugungen und ihrem Selbstkonzept befragt.

5.2 Instrumente

Zur Datenerhebung wurden etablierte Skalen (Dietrich et al., 2019; Gaspard et al., 2015) auf Grundlage der Erwartungs-Wert-Theorie für das Themenfeld KI adaptiert. Dazu wurde das in den ursprünglichen Skalen adressierte Wertobjekt „Mathematik“ durch das Wertobjekt „KI verstehen“ ersetzt. Die Skalen differenzieren zwischen den vier Wertfacetten und dem Selbstkonzept und zeigen theoriekonforme Korrelationen der Facetten untereinander (Menzel et al., under review) und können daher als valide betrachtet werden. Tabelle 1 gibt einen Überblick über die verwendeten Skalen. Alle zeigen zufriedenstellende bis sehr gute Reliabilitäten zu beiden Messzeitpunkten. Alle Items wurden auf einer 6-stufigen Likert-Skala von 1 = *stimmt gar nicht* bis 6 = *stimmt vollkommen* beantwortet.

Fehlende Werte wurden vor den Analysen mittels Multipler Imputation (50 imputierte Datensätze) geschätzt.

Konstrukt	$\alpha(T1) / \alpha(T2)$	# Items	Beispielitem
Intrinsic Value	0,82 / 0,76	3	Es macht mir Spaß, KI zu verstehen.
Attainment Value	0,90 / 0,86	5	Mir ist es wichtig, über die Funktionsweise von KI viel zu wissen.
Utility Value	0,88 / 0,87	8	KI zu verstehen ist sehr nützlich für mich.
Costs	0,80 / 0,90	6	KI zu verstehen erschöpft mich.
Selbstkonzept	0,89 / 0,79	3	KI zu verstehen liegt mir einfach.

Tab. 1: Eingesetzte Instrumente mit Reliabilitäten.

6. Ergebnisse

Zur Beantwortung der Forschungsfragen wurden Varianzanalysen mit Messwiederholung (mixed ANOVA) mit Geschlecht bzw. Kurswahl als Zwischen-subjektfaktoren genutzt. *F*-Werte und Freiheitsgrade wurden für die 50 imputierten Datensätze

nach Rudins Regeln gepoolt und angepasst. Als Effektstärkenmaß wird das für Varianzanalysen übliche partielle η^2 berichtet, welches den Anteil der aufgeklärten Varianz angibt (Rasch et al., 2014). Mit Blick auf Forschungsfrage 1 wurden jeweils die Haupteffekte der Zeit betrachtet. Tabelle 2 gibt einen Überblick über die Mittelwerte der Wertüberzeugungen und des Selbstkonzepts bezüglich des Verständnis von KI vor und nach den Workshops. Auffällig ist, dass die Schüler*innen vor den Workshops ein eher geringes Selbstkonzept bezüglich des Verständnisses von KI aufweisen. Auch die Costs fallen vergleichsweise gering aus. Die übrigen Wertfacetten finden sich im mittleren Bereich.

Konstrukt	T1	T2	η^2
Intrinsic Value	3,95	3,88	0,02
Attainment Value	3,62	3,51	0,02
Utility Value	3,93	3,83	0,02
Costs	2,71	2,97	0,05*
Selbstkonzept	3,22	3,56	0,13***

Tab. 2: Mittelwerte zu beiden Messzeitpunkten T1 und T2 sowie Effektstärken der Unterschiede, Antworten von 1 = *stimmt gar nicht* bis 6 = *stimmt vollkommen*, * $p < 0,05$ *** $p < 0,001$

Während Intrinsic, Attainment und Utility Value nahezu konstant bleiben, zeigen sich leichte Veränderungen bezüglich der Costs und des Selbstkonzepts. So nehmen die Costs KI zu verstehen signifikant zu, allerdings mit geringer Effektstärke ($F(1, 542,93) = 6,405$; $p < 0,05$; $\eta^2 = 0,05$). Gleichzeitig steigt das Selbstkonzept der Schüler*innen signifikant mit mittlerer Effektstärke an ($F(1, 768,65) = 15,939$; $p < 0,001$; $\eta^2 = 0,13$). Damit hat sich nur unsere Hypothese bezüglich des Selbstkonzepts bestätigt, während eine Steigerung von Intrinsic und Utility Value durch die Workshops entgegen unserer Erwartung nicht stattfand.

Zur Beantwortung von Forschungsfrage 2 wurden Varianzanalysen mit Messwiederholung und Geschlecht als Zwischensubjektfaktor durchgeführt. Im Falle von signifikanten Haupteffekten des

Geschlechts wurden zudem posthoc univariate Varianzanalysen zu beiden Messzeitpunkten durchgeführt, um zu prüfen, ob mögliche Unterschiede zu beiden Messzeitpunkten bestehen. Tabelle 3 gibt einen Überblick über die Ergebnisse. Für keine der Wertüberzeugungen oder das Selbstkonzept zeigt sich eine signifikante Interaktion zwischen Geschlecht und Messzeitpunkt. Dementsprechend haben sich Wertüberzeugungen und Selbstkonzept von Mädchen und Jungen nicht signifikant unterschiedlich voneinander verändert. Allerdings zeigen sich für Intrinsic Value ($F(1, 12258,52) = 7,308$; $p < 0,01$; $\eta^2 = 0,06$), Attainment Value ($F(1, 5421,24) = 6,744$; $p < 0,01$; $\eta^2 = 0,06$) und Selbstkonzept ($F(1, 4298,6) = 8,149$; $p < 0,01$; $\eta^2 = 0,07$) signifikante Haupteffekte des Geschlechts mit mittlerer Effektstärke. Dabei berichten Jungen erwartungskonform jeweils höhere Wertüberzeugungen und höheres Selbstkonzept als die Mädchen.

Posthoc ANOVAs zeigen, dass Mädchen und Jungen sich sowohl vor den Workshops als auch danach signifikant bezüglich ihres Intrinsic Values zum Verständnis von KI unterscheiden, wobei Jungen jeweils einen höheren Intrinsic Value berichten mit kleiner Effektstärke (T1: $F(1, 36715,45) = 6,111$; $p < 0,05$; $\eta^2 = 0,05$; T2: $F(1, 129,56) = 6,06$; $p < 0,05$; $\eta^2 = 0,05$). Während sich der Attainment Value vor den Workshops noch klar signifikant mit mittlerer Effektstärke unterscheidet ($F(1, 72660,15) = 6,736$; $p < 0,05$; $\eta^2 = 0,06$), ist der Unterschied im Attainment Value zwischen Mädchen und Jungen nach den Workshops knapp nicht mehr signifikant ($F(1, 95,25) = 3,896$; $p < 0,1$; $\eta^2 = 0,03$). Obwohl die Interaktion zwischen Geschlecht und Messzeitpunkt nicht signifikant ausgefallen ist, scheint sich der Unterschied zwischen Jungen und Mädchen leicht verringert zu haben. Ähnlich wie beim Intrinsic Value, unterscheiden sich Jungen und Mädchen sowohl vor als auch nach den Workshops bezüglich ihres Selbstkonzepts zum Verständnis von KI (T1: $F(1, 934,24) = 6,071$; $p < 0,05$; $\eta^2 = 0,05$; T2: $F(1, 91,25) = 6,532$;

	T1			T2			HE (Geschlecht)	Geschlecht* Zeit
	Männlich (n=48)	Weiblich (n=64)	η^2	Männlich (n=48)	Weiblich (n=64)	η^2	η^2	η^2
Intrinsic Value	4,25	3,76	0,05*	4,15	3,68	0,05*	0,06**	0,01
Attainment Value	3,95	3,40	0,06*	3,74	3,40	0,03 ^t	0,06**	0,01
Utility Value	4,12	3,80	–	3,91	3,80	–	0,02	0,02
Costs	2,66	2,74	–	2,92	2,98	–	0,00	0,00
Selbstkonzept	3,47	3,00	0,05*	3,82	3,39	0,06*	0,07**	0,01

Tab. 3: Mittelwerte getrennt nach Geschlecht zu beiden Messzeitpunkten und Effektstärken der Unterschiede, Antworten von 1 = *stimmt gar nicht* bis 6 = *stimmt vollkommen*, * $p < 0,05$ ** $p < 0,01$ ^t $p < 0,1$

	T1			T2			HE (Kurs)	Kurs*Zeit
	LK (n=77)	Kein LK (n=37)	η^2	LK (n=77)	Kein LK (n=37)	η^2	η^2	η^2
Intrinsic Value	4,09	3,67	0,03 ^t	3,95	3,73	0,02	0,03 ^t	0,02
Attainment Value	3,87	3,15	0,09**	3,66	3,29	0,04*	0,07**	0,03 ^t
Utility Value	4,07	3,63	0,05*	3,90	3,70	0,02	0,04*	0,02
Costs	2,79	2,51	–	2,99	2,87	–	0,01	0,01
Selbstkonzept	3,23	3,23	–	3,55	3,66	–	0,00	0,01

Tab. 4: Mittelwerte getrennt nach Leistungskurswahl zu beiden Messzeitpunkten und Effektstärken der Unterschiede, Antworten von 1 = *stimmt gar nicht* bis 6 = *stimmt vollkommen*, * $p < 0,05$ ** $p < 0,01$ ^t $p < 0,1$

$p < 0,05$; $\eta^2 = 0,06$) mit schwacher bis mittlerer Effektstärke. Zu beiden Messzeitpunkten berichten Jungen ein höheres Selbstkonzept als Mädchen und trauen sich somit eher zu, KI zu verstehen. In beiden Gruppen steigt das Selbstkonzept im Laufe der Workshops ähnlich stark an.

Zur Beantwortung von Forschungsfrage 3 wurden wieder Varianzanalysen mit Messwiederholung und Kurswahl als Zwischensubjektfaktor durchgeführt (vgl. Tabelle 4). Dabei wurden, falls signifikante Haupteffekte der Kurswahl auftraten, ebenfalls posthoc univariate Varianzanalysen zu beiden Messzeitpunkten durchgeführt. Abgesehen vom Attainment Value, bei dem die Interaktion zwischen Kurswahl und Messzeitpunkt nur knapp das Signifikanzniveau verfehlt – allerdings mit schwachem Effekt ($F(1,233,14) = 3,363$; $p < 0,1$; $\eta^2 = 0,03$) – zeigen sich für alle anderen Wertfacetten und das Selbstkonzept deutlich keine signifikanten Interaktionen. Der Attainment Value von Schüler*innen mit Mathematikleistungskurs ist dabei grundsätzlich höher als jener von Schüler*innen, die keinen Mathematikleistungskurs belegt haben, was sich in einem signifikanten Haupteffekt des Messzeitpunktes widerspiegelt ($F(1,5032,45) = 9,056$; $p < 0,01$; $\eta^2 = 0,07$). Im Laufe der Workshops nimmt der Attainment Value der Leistungskurs-Schüler*innen leicht ab, während es bei den Schüler*innen ohne Leistungskurs Mathematik zu einer leichten Zunahme kommt. Dementsprechend zeigen die posthoc ANOVAs, dass sich Leistungskursteilnehmer*innen, wie erwartet, vor den Workshops klar mit mittlerer Effektstärke unterscheiden von Schüler*innen ohne Leistungskurs Mathematik ($F(1,522459,4) = 10,514$; $p < 0,01$; $\eta^2 = 0,09$), während nach den Workshops nur noch ein schwacher Effekt besteht ($F(1,83,1) = 4,217$; $p < 0,05$; $\eta^2 = 0,04$).

Für den Intrinsic Value zeigt sich ein signifikanter Haupteffekt der Kurswahl mit geringer Effektstärke ($F(1,934,24) = 6,071$; $p < 0,05$; $\eta^2 = 0,05$). Die posthoc ANOVAs zeigen jedoch nur für den ersten Messzeitpunkt vor den Workshops einen tendenziell

signifikanten Unterschied ($F(1,370055,3) = 3,88$; $p < 0,1$; $\eta^2 = 0,03$): Leistungskursteilnehmer*innen berichten einen höheren Intrinsic Value. Ähnlich zeigt sich auch beim Utility Value ein signifikanter Haupteffekt der Kurswahl ($F(1,1016,82) = 4,909$; $p < 0,05$; $\eta^2 = 0,04$) mit höherem Utility Value im Falle der Belegung eines Mathematik-Leistungskurses. Allerdings sind die Unterschiede auch hier nur zum Zeitpunkt vor den Workshops signifikant ($F(1,10188,96) = 6,441$; $p < 0,05$; $\eta^2 = 0,05$). Beide Ergebnisse entsprechen unseren Hypothesen. Entgegen unseren Vermutungen konnten wir jedoch keine signifikanten Haupteffekte der Kurswahl in Bezug auf das Selbstkonzept sowie die wahrgenommenen Kosten finden. Schüler*innen mit Mathematikleistungskurs scheinen sich somit bezüglich des Verständnisses von KI nicht stärker einzuschätzen und auch keine höheren Kosten zu empfinden als Schüler*innen in entsprechenden Grundkursen.

7. Diskussion

Ausgangspunkt des vorliegenden Beitrags war, dass ein grundsätzliches Verständnis von KI zukünftig immer wichtiger werden wird. Dies gilt sowohl für berufliche Kontexte als auch den alltäglichen Umgang mit KI-Tools, die informierte Einschätzung von Potentialen sowie Grenzen und Gefahren dieser Systeme sowie deren kompetente Handhabung. Bisherige Studien zeigen, dass Motivation zum Lernen über KI mit einer höheren Lern- und Nutzungsbereitschaft bezüglich KI einhergehen (z. B. Chan & Zhou, 2023; Wang et al., 2023). Daher wurde untersucht, inwiefern eine gezielte Förderung von Wertüberzeugungen und Selbstkonzept zum Verständnis von KI durch KI-Modellierungsworkshops im Rahmen der CAMMP days möglich ist und ob gegebenenfalls verschiedene Lernendengruppen unterschiedlich profitieren.

7.1 Zusammenfassung

Das Ergebnis, dass das Selbstkonzept der Schüler*innen nach den Workshops anstieg, stimmt mit bisherigen Studien überein, die zeigen, dass

unterstützende Lernumgebungen das domänenspezifische Selbstkonzept positiv beeinflussen können (Wang et al., 2023). Da das Selbstkonzept stark mit Leistung und kognitiven Fähigkeiten in einer Domäne korreliert (Bong & Skaalvik, 2003), kann vermutet werden, dass der Lernzuwachs zur grundlegenden Funktionsweise von KI, welche in den Workshops vermittelt wird, durch temporale Vergleiche (Marsh, 1990) sowie Erfolgserlebnisse einen positiven Einfluss auf das Selbstkonzept hatte.

Gleichzeitig konnte ein leichter Anstieg der Costs beobachtet werden, wenngleich mit geringer Effektstärke. Dies lässt sich möglicherweise darauf zurückführen, dass ein vertieftes Verständnis von KI mit einer erhöhten Wahrnehmung von Herausforderungen einhergeht. Des Weiteren ist zu berücksichtigen, dass die Schüler*innen im Rahmen der CAMMP days über einen längeren Zeitraum an einzelnen mathematischen Aufgabenstellungen arbeiten, als sie es möglicherweise aus dem Mathematikunterricht gewohnt sind. Zudem könnten sich die gestiegenen Costs auch darauf zurückführen lassen, dass Inhalte aus unterschiedlichen mathematischen Teilgebieten (bspw. Statistik, Lineare Algebra, Analysis) – einschließlich solcher, die im Mathematikunterricht bereits seit geraumer Zeit nicht mehr behandelt wurden – erforderlich waren. Zu beachten ist auch, dass im Laufe der Workshops für die Lernenden teils unbekannte mathematische Konzepte eingeführt werden.

Möglicherweise haben sich viele Schüler*innen im Rahmen der CAMMP days auch das erste Mal mit den mathematischen Hintergründen von KI-Anwendungen beschäftigt, so dass sie zuvor überhaupt keine Costs in Bezug auf das Verständnis von KI wahrgenommen haben. Die geringe Effektstärke dieser Veränderung deutet jedoch darauf hin, dass die Workshops nicht als überfordernd wahrgenommen wurden. Dennoch hat die Strukturierung der Workshops, sowie der Beginn mit leicht zugänglichen Modellen eine Zunahme der Costs nicht völlig verhindern können.

Gleichzeitig blieben die positiven Wertfacetten nahezu unverändert, insbesondere der Utility Value. Diese Konstanz steht im Kontrast zu den Ergebnissen anderer Studien wie Ng et al. (2023), die eine Steigerung des Utility Value durch projektbasiertes Lernen zeigen konnten. Eine mögliche Erklärung ist, dass die Workshops zwar die technische Relevanz von KI betonten, jedoch keine ausreichend starke Verbindung zu den individuellen Zielen und Interessen der Schüler*innen herstellten. Zudem könnte der Reflexion

der Nützlichkeit eines Verständnisses von KI mehr Zeit eingeräumt werden. In Value-Interventionen zum Fach Mathematik hat sich beispielsweise das Schreiben von Essays oder Briefen als förderlich erwiesen (Harackiewicz & Priniski, 2018).

Wie erwartet, ergaben sich keine signifikanten Entwicklungen des Attainment Value, der eher als stabil gilt – insbesondere bei kurzen Interventionen. Überraschend hingegen ist das Ausbleiben einer Steigerung des Intrinsic Value trotz sorgfältiger Auswahl der Kontexte.

Bisherige Studien haben uneinheitliche Ergebnisse in Bezug auf Genderunterschiede bei KI-bezogener Motivation berichtet. Sowohl vor als auch nach den Workshops berichteten Jungen signifikant höhere Intrinsic und Attainment Value sowie ein stärkeres Selbstkonzept, was die Befunde zur Geschlechterdifferenz in KI-bezogener Motivation von Kim und Lee (2023) sowie Lin et al. (2021) bestätigt. Fehlende Interaktionen zwischen Geschlecht und Messzeitpunkt zeigen, dass Mädchen und Jungen ähnliche Entwicklungen ihrer Motivation durchlaufen haben. So steigt das Selbstkonzept in beiden Gruppen vergleichbar stark an.

Die anfänglich höheren Werte in Intrinsic, Attainment und Utility Value bei Schüler*innen mit Mathematikleistungskurs stehen im Einklang mit der Forschung, die zeigt, dass mathematische Vorkenntnisse und Interessen oft mit einer stärkeren Identifikation mit technisch-naturwissenschaftlichen Themen korrelieren (Collie & Martin, 2024). Zwar finden sich für Intrinsic und Utility Value nach der Intervention keine signifikanten Unterschiede mehr, die fehlende Interaktion zwischen Kurswahl und Messzeitpunkt zeigt jedoch, dass keine signifikant unterschiedlichen Entwicklungen in beiden Schüler*innengruppen abgelaufen sind. Lediglich beim Attainment Value berichten Schüler*innen mit Leistungskurs Mathematik auch nach den Workshops noch mehr Zustimmung.

Überraschend ist, dass Schüler*innen mit Mathematikleistungskurs kein stärkeres Selbstkonzept aufweisen als Lernende ohne Leistungskurs. Dies liegt vermutlich daran, dass in Deutschland – im Gegensatz zu anderen Ländern – auch in Leistungskursen KI noch nicht thematisch in Lehrplänen verankert ist.

7.2 Grenzen und Stärken der Studie

Die größte Limitation der vorliegenden Studie ist das Fehlen einer Kontrollgruppe, sodass Änderungen in Wertüberzeugungen und Selbstkonzept nicht

zweifelsfrei auf die Workshops zurückgeführt werden können. Allerdings war die Zeit zwischen Prä- und Posttest mit einem halben Tag sehr gering, so dass es unwahrscheinlich scheint, dass signifikante Änderungen ohne gezielte Intervention zu erwarten wären. Gleichzeitig könnte die Intervention für die Änderung der Wertfacetten (insbesondere des Attainment Value) zu kurz gewesen sein. Aufgrund der geringen Teilstichproben in den einzelnen Workshops, wurde auf eine getrennte Auswertung der drei Workshops verzichtet. Obwohl die Kontexte in allen drei Workshops bezogen auf Authentizität und Relevanz denselben Kriterien genügen, können unterschiedliche Effekte in den Workshops durch Unterschiede in den Inhalten oder beteiligten Personen nicht gänzlich ausgeschlossen werden. Zudem lassen sich bei Selbstauskunftsinstrumenten übliche Effekte wie etwa soziale Erwünschtheit nicht vollständig ausschließen.

Sicherlich können die in den Workshops entwickelten stark geleiteten Lernumgebungen nicht identisch im Regelunterricht eingesetzt werden. Die in der Entwicklung genutzten Designprinzipien lassen sich jedoch auch im Unterricht umsetzen (siehe 7.3).

Eine klare Stärke der vorliegenden Studie ist die Verankerung in der Erwartungs-Wert-Theorie und das simultane Erfassen verschiedener Wertfacetten sowie des Selbstkonzepts, was differenziertere Einblicke ermöglicht, als wenn Wertüberzeugungen zu KI in nur einer gemeinsamen Skala untersucht werden.

7.3 Implikationen für Forschung und Praxis

Zukünftige Studien könnten zum Beispiel über Interviews Einblicke in die Gründe für (ausbleibende) Veränderungen der Wertüberzeugungen und des Selbstkonzepts der Schüler*innen im Laufe der Workshops geben. Zudem wäre ein stärkerer Fokus darauf, welche Schüler*innen in welchem Maße von den Bausteinen der Workshops profitieren, vielversprechend – zum Beispiel durch den Einsatz eines Vorwissenstests zu KI.

Für die Weiterentwicklung der CAMMP days lassen sich aus den Ergebnissen einige Rückschlüsse ziehen, die auch für eine Thematisierung von KI im Mathematikunterricht übertragbar sind. Die Strategien zur Förderung des Selbstkonzepts – explizites Anknüpfen an das mathematische Vorwissen, Einstieg mit einfachen Modellen, welche frühzeitig Erfolgserlebnisse ermöglichen, regelmäßiges gezieltes Feedback sowie klare Strukturierung der Lernumgebung – scheinen effektiv gewesen zu sein und können auch bei der Behandlung von KI im Unterricht umgesetzt

werden. Dazu können gezielt KI-Anwendungen ausgewählt werden, deren mathematischer Hintergrund (weitestgehend) zuvor im Unterricht bereits thematisiert wurde. Ein mehrfaches Durchlaufen des Modellierungskreislaufes mit zunächst recht einfachen, angeleiteten Modellen lässt sich ebenfalls im Unterricht umsetzen. Ideen für den Unterricht finden sich beispielsweise bei Biehler und Schönbrodt (2024).

Mit Blick auf den Utility Value scheint eine stärkere selbstgesteuerte Reflexion des Nutzens eines Verständnisses für KI notwendig. Harackiewicz und Priniski (2018) folgend bietet sich hier eine längere Reflexionsphase an, bei der die Schüler*innen selbst Argumente sammeln und diese zum Beispiel in Form eines Briefes an Freunde oder Verwandte aufbereiten. Im Mathematikunterricht bietet sich dies beispielsweise als Hausaufgabe zum Abschluss einer Einheit zu KI an. Zudem wäre es vorteilhaft, verschiedene Facetten des Utility Value zu betrachten. So unterscheiden Gaspard et al. (2015) den Utility Value im Sinne von Nützlichkeit für die weitere Schullaufbahn, die berufliche Zukunft, die Gesellschaft und das alltägliche Leben. Eine Ansprache aller dieser Facetten während der Workshops und eine Förderung des Transfers des Gelernten auf weitere Anwendungsbereiche von KI könnte daher einen stärkeren Einfluss auf den Utility Value haben.

Um auch den Intrinsic Value zu steigern, müssen die Kontexte noch stärker auf die Interessen der Schüler*innen abgestimmt werden. Im Unterricht ließe sich dies beispielsweise mit einer vorherigen Befragung zum Interesse der Schüler*innen umsetzen.

8. Fazit

Wertüberzeugungen und Selbstkonzept in Bezug auf das Verständnis von KI können einen starken Einfluss auf Nutzungsintentionen sowie die Bereitschaft zum Lernen in Bezug auf KI haben, so dass eine entsprechende Förderung relevant ist. Die vorliegende Studie zeigt, dass KI-Modellierungswshops wie die CAMMP days das Selbstkonzept fördern können, nicht jedoch die Wertüberzeugungen. Weitere Forschung ist notwendig, um Gestaltungsprinzipien für Interventionen zu prüfen, welche auch KI-bezogene Wertüberzeugungen fördern.

Literatur

- Acosta-Enriquez, B. G., Arbulú Perez Vargas, C. G., Jordan, O. H., Arbulú Ballesteros, M. A. & Paredes Morales, A. E. (2024). Exploring attitudes toward ChatGPT among college students: An empirical analysis of cognitive, affective, and behavioral components using path analysis. *Computers and*

- Education: Artificial Intelligence*, 7, 100320. <https://doi.org/10.1016/j.caeai.2024.100320>
- Biehler, R. & Schönbrodt, S. (Hrsg.) (2024). *mathematik lehren*, 244.
- Blum, W. (1985). Anwendungsorientierter Mathematikunterricht in der didaktischen Diskussion? *Mathematische Semesterberichte*, 32(2), 195–232.
- Bong, M. & Skaalvik, E. (2003). Academic Self-Concept and Self-Efficacy: How Different Are They Really? *Educational Psychology Review*, 15(1), 1–40. <https://doi.org/10.1023/A:1021302408382>
- Brown, J. P. & Stillman, G. A. (2017). Developing the roots of modelling conceptions: 'mathematical modelling is the life of the world.' *International Journal of Mathematical Education in Science and Technology*, 48(3), 353–373. <https://doi.org/10.1080/0020739X.2016.1245875>
- Burkhardt, H. (1989). Mathematical modelling in the curriculum. In W. Blum, J. S. Berry, R. Biehler, D. Huntley, G. Kaiser-Messmer & L. Profke (Hrsg.), *Applications and modelling in learning and teaching mathematics*, 1–11. Ellis Horwood Limited.
- Casal-Otero, L., Catala, A., Fernández-Morante, C. et al. AI literacy in K-12: a systematic literature review. *International Journal of STEM Education*, 10, 29 (2023). <https://doi.org/10.1186/s40594-023-00418-7>
- Chan, C. K. Y. & Hu, W. (2023). Students' voices on generative AI: perceptions, benefits, and challenges in higher education. *International Journal of Educational Technology in Higher Education*, 20(43). <https://doi.org/10.1186/s41239-023-00411-8>
- Chan, C.K.Y. & Zhou, W. (2023). An expectancy value theory (EVT) based instrument for measuring student perceptions of generative AI. *Smart Learn. Environ*, 10(64). <https://doi.org/10.1186/s40561-023-00284-4>
- Chiu, T. K., Meng, H., Chai, C. S., King, I., Wong, S. & Yam, Y. (2021). Creation and evaluation of a pretertiary artificial intelligence (AI) curriculum. *IEEE Transactions on Education*, 65(1), 30–39. <https://doi.org/10.1109/TE.2021.3085878>
- Chiu, T. K. F., Moorhouse, B. L., Chai, C. S. & Ismailov, M. (2023). Teacher support and student motivation to learn with Artificial Intelligence (AI) based chatbot. *Interactive Learning Environments*, 32(7), 3240–3256. <https://doi.org/10.1080/10494820.2023.2172044>
- Collie, R. J. & Martin, A. J. (2024). Teachers' motivation and engagement to harness generative AI for teaching and learning: The role of contextual, occupational, and background factors. *Computers and Education: Artificial Intelligence*, 6, 100224. <https://doi.org/10.1016/j.caeai.2024.100224>
- Dietrich, J., Moeller, J., Guo, J., Viljaranta, J. & Kracke, B. (2019). In-the-Moment Profiles of Expectancies, Task Values, and Costs. *Frontiers in Psychology*, 10, 1662. <https://doi.org/10.3389/fpsyg.2019.01662>
- Druga, S., Vu, S. T., Likhith, E. & Qiu, T. (2019). Inclusive AI literacy for kids around the world. In P. Blikstein & N. Holbert (Hrsg.), *Proceedings of FabLearn 2019* (S. 104–111). ACM Publishing.
- Eccles, J. S. & Wigfield, A. (2020). From expectancy-value theory to situated expectancy-value theory: A developmental, social cognitive, and sociocultural perspective on motivation. *Contemporary Educational Psychology*, 61, 101859. <https://doi.org/10.1016/j.cedpsych.2020.101859>
- Eccles, J. S. & Wigfield, A. (2023). Expectancy-value theory to situated expectancy-value theory: Reflections on the legacy of 40+ years of working together. *Motivation Science*, 9(1), 1–12. <https://doi.org/10.1037/mot0000275>
- Eickelmann, B., Fröhlich, N., Bos, W., Gerick, J., Goldhammer, F., Schaumburg, H., Schwippert, K., Senkbeil, M. & Vahrenhold, J. (2024). ICILS 2023 #Deutschland: Computer- und informationsbezogene Kompetenzen und Kompetenzen im Bereich Computational Thinking von Schüler*innen im internationalen Vergleich. Waxmann. <https://doi.org/10.31244/9783830999492>
- Frank, M., Roeckerath, C. & Schönbrodt, S. (2022). Einführung. In M. Frank & C. Roeckerath (Hrsg.) *Neue Materialien für einen realitätsbezogenen Mathematikunterricht 9. Realitätsbezüge im Mathematikunterricht*. Springer. https://doi.org/10.1007/978-3-662-63647-3_1
- Gaspard, H., Dicke, A.-L., Flunger, B., Schreier, B., Häfner, I., Trautwein, U. & Nagengast, B. (2015). More value through greater differentiation: Gender differences in value beliefs about math. *Journal of Educational Psychology*, 107(3), 663–677. <https://doi.org/10.1037/edu0000003>
- Harackiewicz, J. M. & Priniski, S. (2018). Improving student outcomes in higher education: The science of targeted interventions. *Annual Review of Psychology*, 69, 409–435. <https://doi.org/10.1146/annurev-psych-122216-011725>
- Hofmann, S. (2025). *Entwicklung von computergestützten Lehr- und Lernmaterialien für einen realitätsbezogenen Mathematikunterricht zum Kontext Sprachverarbeitung* (Dissertation, Karlsruher Institut für Technologie). Karlsruher Institut für Technologie (KIT). <https://doi.org/10.5445/IR/1000182142>
- Hulleman, C. S. & Harackiewicz, J. M. (2009). Promoting interest and performance in high school science classes. *Science*, 326, 1410–1412. <https://doi.org/10.1126/science.1177067>
- Jang, Y., Choi, S. & Kim, H. (2022). Development and validation of an instrument to measure undergraduate students' attitudes toward the ethics of artificial intelligence (AT-EAI) and analysis of its difference by gender and experience of AI education. *Education and Information Technologies*, 27, 13163. <https://doi.org/10.1007/s10639-022-11086-5>
- Kaiser, G. & Schwarz, B. (2010). Authentic modelling problems in mathematics education – Examples and experiences. *Journal für Mathematik-Didaktik*, 31, 51–76. <https://doi.org/10.1007/s13138-010-0001-3>
- Katsantonis, A. & Katsantonis, I.G. (2024). University Students' Attitudes toward Artificial Intelligence: An Exploratory Study of the Cognitive, Emotional, and Behavioural Dimensions of AI Attitudes. *Educ. Sci.*, 14, 988. <https://doi.org/10.3390/educsci14090988>
- Kelly, S., Kaye, S. A. & Oviedo-Trespalacios, O. (2023). What factors contribute to acceptance of artificial intelligence? A systematic review. *Telematics and Informatics*, 77, 101925. <https://doi.org/10.1016/j.tele.2022.101925>
- Kim, SW. & Lee, Y. (2024). Investigation into the Influence of Socio-Cultural Factors on Attitudes toward Artificial Intelligence. *Educ Inf Technol*, 29, 9907–9935. <https://doi.org/10.1007/s10639-023-12172-y>
- KMK. (2024). Handlungsempfehlung für die Bildungsverwaltung zum Umgang mit Künstlicher Intelligenz in schulischen Bildungsprozessen. Themenspezifische Handlungsempfehlung (Beschluss der Bildungsministerkonferenz vom 10.10.2024). https://www.kmk.org/fileadmin/veroeffentlichungen_beschluesse/2024/2024_10_10-Handlungsempfehlung-KI.pdf

- Lai, C. Y., Cheung, K. Y. & Chan, C.S. (2023). Exploring the role of intrinsic motivation in ChatGPT adoption to support active learning: An extension of the technology acceptance model. *Computers and Education: Artificial Intelligence*, 5, 100178. <https://doi.org/10.1016/j.caeai.2023.100178>
- Laupichler, M. C., Aster, A., Schirch, J. & Raupach, T. (2022). Artificial intelligence literacy in higher and adult education: A scoping literature review. *Computers and Education: Artificial Intelligence*, 3, 100101. <https://doi.org/10.1016/j.caeai.2022.100101>
- Lin, P. Y., Chai, C. S., Jong, M. S. Y., Dai, Y., Guo, Y. & Qin, J. (2021). Modeling the structural relationship among primary students' motivation to learn artificial intelligence. *Computers and Education: Artificial Intelligence*, 2, 100006. <https://doi.org/10.1016/j.caeai.2020.100006>
- Long, D. & Magerko, B. (2020). What is AI Literacy? Competencies and Design Considerations. In Bernhaupt, R. Mueller, F. (Hrsg.), *CHI '20: Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*. <https://doi.org/10.1145/3313831.3376727>
- Marsh, H. (1990). Influences of Internal and External Frames of Reference on the Formation of Math and English Self-Concepts. *Journal of Educational Psychology*, 82(1), 107–116. <https://doi.org/10.1037/0022-0663.82.1.107>
- Menzel, M., Hofmann, S., Schönbrodt, S., Weygandt, B., Bauer, S. & Geisler, S. (under review). Do students value AI? Self-concept, values and perceptions of secondary students regarding AI. *Computers and Education: Artificial Intelligence*.
- mmb Institut, DFKI & DIPF. (2021). *Trendstudie KI@Bildung: Lehren und Lernen in der Schule mit Werkzeugen Künstlicher Intelligenz: Schlussbericht*. Deutsche Telekom Stiftung. <https://www.telekom-stiftung.de/sites/default/files/files/media/publications/KI%20Bildung%20Schlussbericht.pdf>
- Ng, D. T. K., Leung, J. K. L., Chu, S. K. W. & Qiao, M. S. (2021). Conceptualizing AI literacy: An exploratory review. *Computers and Education: Artificial Intelligence*, 2, 100041. <https://doi.org/10.1016/j.caeai.2021.100041>
- Ng, D. T. K., Xinyu, C., Leung, J. K. L. & Chu, S. K. W. (2023). Fostering students' AI literacy development through educational games: AI knowledge, affective and cognitive engagement. *J. Comput. Assist. Learn.* <https://doi.org/10.1111/jcal.13009>
- Ng, D.T.K., Su, J. & Chu, S.K.W. (2024) Fostering Secondary School Students' AI Literacy through Making AI-Driven Recycling Bins. *Educ Inf Technol*, 29, 9715–9746. <https://doi.org/10.1007/s10639-023-12183-9>
- Niss, M. (1992). Applications and Modelling in School Mathematics - Directions for Future Development. In I. Wirsup & R. Streit (Hrsg.), *Development in School Mathematics Education Around the World* (S. 346–361). NCTM.
- Pörn, R., Braskén, M., Wingren, M. & Andersson, S. (2024). Attitudes towards and expectations on the role of artificial intelligence in the classroom among digitally skilled Finnish K-12 mathematics teachers. *LUMAT: International Journal on Math, Science and Technology Education*, 12(3), 53–77. <https://doi.org/10.31129/LUMAT.12.3.2102>
- Rasch, B., Frieze, M., Hofmann, W. & Naumann, E. (2014). *Quantitative Methoden 2. Einführung in die Statistik für Psychologen und Sozialwissenschaftler*. Springer.
- Schönbrodt, S. & Frank, M. (2022). Data Science and Machine Learning in mathematics education: High School students working on the Netflix Prize. *CERME12-Proceedings*. <https://hal.science/hal-03754716v1>
- Schönbrodt, S., Camminady, T. & Frank, M. (2021). Mathematische Grundlagen der Künstlichen Intelligenz im Schulunterricht – Chancen für eine Bereicherung des Unterrichts in linearer Algebra. *Mathematische Semesterberichte*, 69, 73–101. <https://doi.org/10.1007/s00591-021-00310-x>
- Schönbrodt, S., Wohak, K. & Frank, M. (2022). Digital tools to enable collaborative mathematical modeling online. *Modeling in Science Education and Learning*, 15(1), 151–174. <https://doi.org/10.4995/msel.2022.16269>
- Schulze Elfringhoff, M. & Schukajlow, S. (2021). What makes a modelling problem interesting? Sources of situational interest in modelling problems. *Quadrante: Revista de Investigação Em Educação Matemática*, 30(1), 8–30. <https://doi.org/10.48489/quadrante.23861>
- Schukajlow, S., Blum, W. & Krämer, J. (2011). Förderung der Modellierungskompetenz durch selbständiges Arbeiten im Unterricht mit und ohne Lösungsplan. *Praxis der Mathematik in der Schule*, 53(2), 40–45.
- Stöhr, C, Ou, A. W. & Malmström, H. (2024). Perceptions and usage of AI chatbots among students in higher education across genders, academic levels and fields of study. *Computers and Education: Artificial Intelligence*, 7, 100259. <https://doi.org/10.3389/fpsyg.2019.01662>
- van Vorst, H., Fechner, S. & Sumfleth, E. (2018). Unterscheidung von Kontexten für den Chemieunterricht. *Zeitschrift für Didaktik der Naturwissenschaften*, 24(1), 167–181 <https://doi.org/10.1007/s40573-018-0081-z>
- Vos, P. (2011). What is 'authentic' in the teaching and learning of mathematical modelling?. *Trends in teaching and learning of mathematical modelling: ICTMA14*, 713–722. https://doi.org/10.1007/978-94-007-0910-2_68
- Vos, P. (2018). "How real people really need mathematics in the real world"—Authenticity in mathematics education. *Education Sciences*, 8(4), 195. <https://doi.org/10.3390/educsci8040195>
- Vuorikari, R., Kluzer, S. & Punie, Y. (2022). *DigComp 2.2: The Digital Competence Framework for Citizens – With new examples of knowledge, skills and attitudes*. <https://publications.jrc.ec.europa.eu/repository/handle/JRC128415>
- Wang, Y. M., Wei, C. L., Lin, H. H., Wang, S. C. & Wang, Y. S. (2022). What drives students' AI learning behavior: a perspective of AI anxiety. *Interactive Learning Environments*, 32(6), 2584–2600. <https://doi.org/10.1080/10494820.2022.2153147>
- Wang, F., King, R.B., Chai, C.S. & Zhou, Y. (2023). University students' intentions to learn artificial intelligence: the roles of supportive environments and expectancy–value beliefs. *Int J Educ Technol High Educ*, 20(51). <https://doi.org/10.1186/s41239-023-00417-2>
- Wigfield, A. & Eccles, J. S. (2000). Expectancy–Value Theory of Achievement Motivation. *Contemporary Educational Psychology*, 25(1), 68–81. <https://doi.org/10.1006/ceps.1999.1015>
- Wigfield, A., Eccles, J. S. & Möller, J. (2020). How Dimensional Comparisons Help to Understand Linkages Between Expectancies, Values, Performance, and Choice. *Educational Psychology Review*, 32(3), 657–680. <https://doi.org/10.1007/s10648-020-09524-2>
- Wohak, K., Sube, M., Schönbrodt, S., Frank, M. & Roeckerath, C. (2021). Authentische und relevante Modellierung mit

Schülerinnen und Schülern an nur einem Tag?! In M. Bracke, M. Ludwig & K. Vorhölter (Hrsg.) *Modellierungsprojekte mit Schülerinnen und Schülern. Realitätsbezüge im Mathematikunterricht*, Springer. https://doi.org/10.1007/978-3-658-33012-5_4

Yurt, E. & Kasarci, I. (2024). A Questionnaire of Artificial Intelligence Use Motives: A contribution to investigating the connection between AI and motivation. *International Journal of Technology in Education (IJTE)*, 7(2), 308–325. <https://doi.org/10.46328/ijte.725>

Zawacki-Richter, O., Marín, V. I., Bond, M. & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education—where are the educators?. *International journal of educational technology in higher education*, 16(1), 1-27. <https://doi.org/10.1186/s41239-019-0171-0>

Anschrift der Verfasser*innen

Sebastian Geisler
Universität Potsdam
Institut für Mathematik
Karl-Liebknechtstr. 24-25
14476 Potsdam
sebastian.geisler@uni-potsdam.de

Marielena Menzel
Universität Potsdam
Institut für Mathematik
Karl-Liebknecht-Str. 24-25
14476 Potsdam
marielena.menzel@uni-potsdam.de

Stephanie Hofmann
Karlsruher Institut für Technologie (KIT)
Institut für Angewandte und Numerische Mathematik
Zirkel 2
76131 Karlsruhe
stephanie.hofmann@kit.edu

Benedikt Weygandt
Freie Universität Berlin
Institut für Mathematik, Didaktik der Mathematik
Arnimallee 3
14195 Berlin
weygandt@math.fu-berlin.de

Sebastian Bauer
Karlsruher Institut für Technologie (KIT)
Institut für Algebra und Geometrie
Englerstraße 2
76131 Karlsruhe
sebastian.bauer2@kit.edu

Sarah Schönbrodt
Paris Lodron Universität Salzburg
Fachbereich Mathematik, AG Didaktik der Mathematik
Hellbrunnerstraße 34
5020 Salzburg
sarah.schoenbrodt@plus.ac.at